

基于随机自注意力和动量对比学习的自监督序列推荐方法

余正涛^{1,2}, 孙资钦^{1,2}, 张勇丙^{1,2}, 高盛祥^{1,2}, 黄于欣^{1,2}, 谭凯文^{1,2}

(1. 昆明理工大学信息工程与自动化学院, 云南 昆明 650000; 2. 云南省人工智能重点实验室, 云南 昆明 650000)

摘要: 序列推荐利用用户历史序列行为建模用户兴趣并进行内容推荐, 常被用于新闻、广告和电子商务等领域。基于对比学习的自监督序列推荐是当前研究热点, 然而, 真实的序列数据具有动态不确定, 且对比学习中存在采样偏移问题, 限制了推荐的性能。为了缓解这些问题, 提出基于随机自注意力和动量对比学习的自监督序列推荐方法, 其中随机自注意力用于缓解序列动态不确定问题, 动量对比学习用于缓解对比学习中存在采样偏移问题。为验证模型性能, 在 Beauty、Office、Yelp 和 Toys 4 个常用数据集上的实验结果表明, 该方法在 HR@K、NDCG@K 等多个指标上均优于其他基线模型, 展示了该方法在准确性和鲁棒性方面的显著提升。

关键词: 序列推荐; 动量对比学习; Wasserstein 距离; 自监督学习; 自注意力

中图分类号: TP391

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0070193

Self-Supervised Sequence Recommendation Method Based on Random Self-Attention and Momentum Contrastive Learning

YU Zhengtao^{1,2}, SUN Ziqin^{1,2}, ZHANG Yongbing^{1,2}, GAO Shengxiang^{1,2}, HUANG Yuxin^{1,2}, TAN Kaiwen^{1,2}

(1. School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650000, Yunnan, China;

2. Yunnan Key Laboratory of Artificial Intelligence, Kunming 650000, Yunnan, China)

【Abstract】 Sequence recommendation utilizes user historical sequence behavior to model user interests and provide content recommendations, and is commonly employed in sectors such as news, advertising, and e-commerce. Self-supervised sequence recommendation based on contrastive learning is a current research hotspot. However, real sequence data are dynamically uncertain, and sampling biases exist in contrastive learning, which limit the performance of recommendations. To mitigate these issues, this paper proposes a self-supervised sequence recommendation method based on stochastic self-attention and momentum contrastive learning. Stochastic self-attention is used to alleviate the uncertainty of sequence dynamics, and momentum contrastive learning is used to mitigate the sampling bias problem in contrastive learning. To validate the performance of the model, experiments are conducted on three datasets: Beauty, Office, Yelp, and Toys. The results demonstrate that the proposed method outperforms other baseline models across several metrics, including HR@K and NDCG@K, indicating significant improvements in both accuracy and robustness.

【Key words】 sequence recommendation; momentum contrastive learning; Wasserstein distance; self-supervised learning; self-attention

0 引言

序列推荐系统^[1-3]旨在通过分析用户历史交互序列数据, 建模用户的偏好、兴趣和行为模式^[4-7], 从而更精准地提供个性化推荐服务。近年来, 对比学习因其强大的表示学习能力被应用于自监督序列推荐中, 例如, S3-Rec^[8]、SGL^[9]、ContraRec^[10]等模型通过构造正负样本进行对比学习, 以获得更好的序列嵌入表示。此外, FAN 等^[11]提出了基于概率分

布的序列正负样本表示, 进一步提升了推荐效果。然而, 现有方法大多假设用户兴趣是确定的, 忽略了用户行为的随机性。此外, 负样本仅从批次中提取, 存在采样偏移问题, 这些因素可能导致模型性能下降, 影响推荐的准确性和可靠性。

本文提出一种基于随机自注意力和动量对比学习的序列推荐方法。该方法包含随机嵌入层、基于 Wasserstein 距离的随机自注意力编码器和基于实例加权动量对比学习的编码器。随机嵌入层将用户

基金项目: 国家自然科学基金联合基金重点项目(U23A20388); 国家自然科学基金(U21B2027, 62376111, 62266028, 62266027); 云南省重点研发计划(202303AP140008, 202401BC070021, 202103AA080015); 云南省科技人才与平台计划(202105AC160018); 云南省基础研究项目(202301AT070393)。

作者简介: 余正涛, 男, 教授、博士, 主研方向为人工智能、自然语言处理; 孙资钦, 硕士; 张勇丙, 博士; 高盛祥、黄于欣, 教授、博士; 谭凯文, 副教授、博士。

收稿日期: 2024-08-05

修回日期: 2024-10-27

E-mail: tkwan@kust.edu.cn

序列嵌入为椭圆高斯分布,然后通过 Wasserstein 距离替代注意力机制中的点积操作,提高训练稳定性。同时,动量对比学习引入记忆队列,将负样本的选取范围扩大,并采用加权采样技术降低假阴性负样本的影响,从而缓解采样偏移问题。最后在 Beauty、Office、Yelp 和 Toys 4 个数据集上进行实验,对比本文方法与基线方法的准确性和鲁棒性。

1 相关工作

1.1 序列推荐方法

在传统推荐方法中,ZIMDARS 等^[12]首先将马尔可夫链引入网页推荐,通过概率决策树提取序列模式并预测下一个点击。YAP 等^[13]提出了一种分数机制来优化个性化序列推荐,能够有效学习用户特定的序列重要性知识。随着深度学习方法的兴起,LI 等^[14]采用注意力机制的混合编码器建模用户行为和意图,捕捉用户兴趣。TAN 等^[15]通过数据增强和输入数据分布变化建模提升推荐性能。近年来,Transformer 的兴起推动了基于 Transformer 的序列推荐算法的发展^[16-18],SUN 等^[16]提出双向 Transformer,探索非有序序列的有效性。WANG 等^[19]结合序列预测目标与自监督学习目标,提高模型性能和泛化能力。

1.2 自监督对比学习方法

自监督对比学习方法研究热点包括:通过互信息最大化机制建模交互序列局部与全局特征关系,对原数据序列进行增强,通过对比学习正负样本差异。MA 等^[20]通过将用户序列划分为子序列减小相近表征距离学习物品表征。YU 等^[21]提出多通道超图卷积网络,通过聚合多通道嵌入信息生成用户表征。ZHUO 等^[8]设计固定大小队列存储物品表征,进行负采样实现序列增强。XIE 等^[18]假设对同一组特征进行不同数据增强互为正例,通过最大化一致性对序列表征编码。YAO 等^[22]对输入物品特征进行掩码或删除操作,学习分类特征内部关系。SUN 等^[16]提出内存增强的多实例对比预测编码模型,采用基于多个实例的噪声对比估计损失。FAN 等^[11]在基于对比学习的自监督序列建模上构造序列正负样本的概率分布表示,提升推荐效果。

2 定义与讨论

本文提出基于 Wasserstein 距离和动量对比学习的自监督序列推荐方法。首先对序列推荐进行问题定义,然后给出基于自监督学习的推荐系统的一般计算过程。

2.1 问题定义

序列推荐系统根据用户带有时间的历史物品交互序列,预测用户在下一时刻要交互的物品,用 \mathcal{V} 表示所有物品的集合,用 \mathcal{U} 表示所有用户的集合,用户 $u \in \mathcal{U}$ 和商品的交互序列为 $S_u = [v_{u_1}, v_{u_2}, \dots, v_{u_{|S_u|}}]$,其中 $v_{u_i} \in \mathcal{V}$ 表示序列中的第 i 个交互项。序列推荐的目标是给出一个 Top- N 的物品排序列表作为交互序列的下一个可能项,即:

$$P(v_{u_{|S_u|+1}} = v | S_u) \quad (1)$$

2.2 序列推荐的自注意力机制

本文采用自注意力机制作为序列推荐编码器的核心组件,因此在介绍本文方法前先简要描述自注意力机制用于序列推荐任务。具体而言,给定用户交互序列 S_u 和最大序列长度 n ,如 S_u 的序列长度大于 n 则通过移除最早的项来截断序列,如果长度小于 n 则通过填充 0,进而获得定长序列 $s = (s_1, s_2, \dots, s_n)$ 。定义嵌入表 $M \in \mathbb{R}^{|\mathcal{V}| \times d}$,其中 d 是嵌入维数,将可学习的位置嵌入 $P \in \mathbb{R}^{n \times d}$,并添加到序列嵌入中,进而得到用户 u 的序列嵌入为:

$$\hat{E}_{S_u} = E_{\text{Emb}}(S_u) = [m_{s_1} + p_{s_1}, m_{s_2} + p_{s_2}, \dots, m_{s_n} + p_{s_n}] \quad (2)$$

随后,自注意力机制通过序列中物品间的点积来捕获物品间的关联性,该计算过程如下:

$$S_{\text{Self-attention}}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V \quad (3)$$

式中: $Q = \hat{E}_{S_u} W_Q$; $K = \hat{E}_{S_u} W_K$; $V = \hat{E}_{S_u} W_V$ 。此外,还使用了 Transformer 中的其他模块,包括逐点前馈网络、残差连接和归一化。

3 模型

在上述自注意力框架上,本文提出基于随机自注意力和动量对比学习的序列推荐方法,总体框架如图 1 所示,其中随机自注意力由随机嵌入层和基于 Wasserstein 距离的随机自注意力编码器两部分实现,动量对比学习由随机嵌入层和基于实例加权动量对比学习的编码器实现。此外,模型通过推荐损失和动量对比损失进行训练。

3.1 随机嵌入层

由于用户兴趣是不确定的,因此在顺序环境中建模用户兴趣时,动态不确定性^[23-26]是一个重要的组成部分。本文参照 STOSA^[27]用不确定性建模捕捉用户兴趣并采用分布表示物品序列,与单一的固定嵌入相比,分布表示引入了不确定性,并提供了更大的灵活性。具体而言,使用多维椭圆高斯分布表

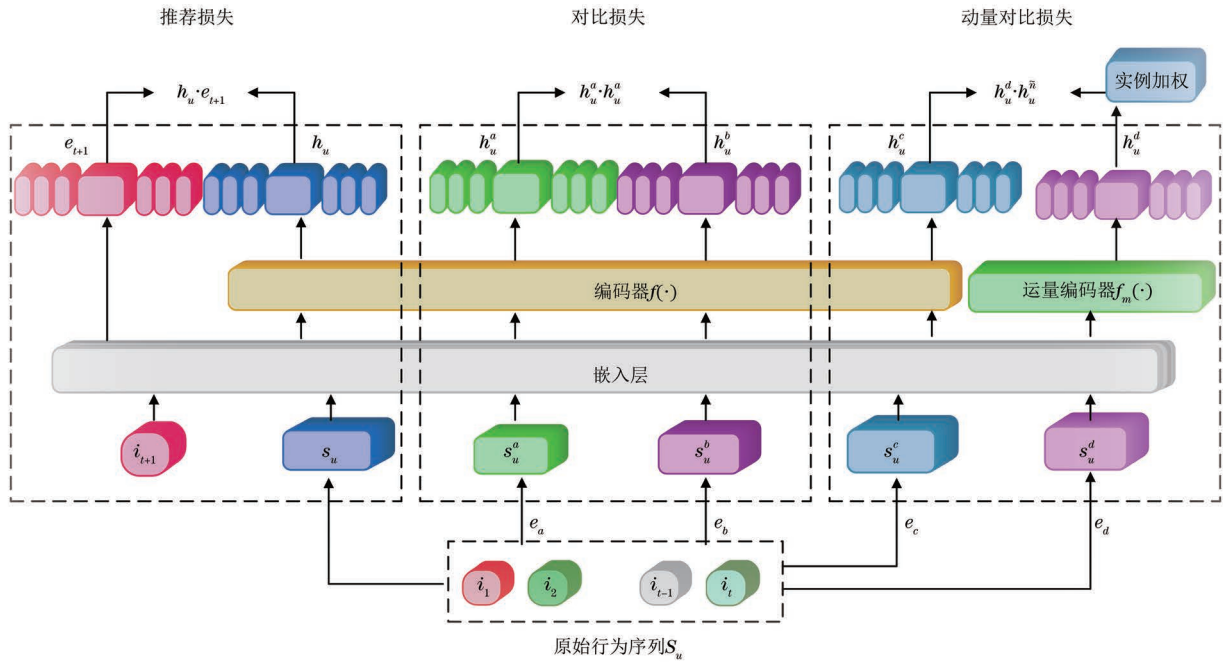


图 1 基于随机自注意力和动量对比学习的自监督序列推荐方法总体框架

Fig. 1 Overall framework of self-supervised sequence recommendation method based on random self-attention and momentum contrastive learning

示物品。对于所有商品,定义一个均值嵌入表 $M_\mu \in \mathbb{R}^{|\mathcal{V}| \times d}$ 和协方差嵌入表 $M_\Sigma \in \mathbb{R}^{|\mathcal{V}| \times d}$,与式(1)类似,用户 u 的均值和协方差的序列嵌入如下:

$$\begin{aligned} \hat{E}_{\mu_{S_u}} &= E_{\text{Emb}\mu}(S_u) \\ \hat{E}_{\Sigma_{S_u}} &= E_{\text{Emb}\Sigma}(S_u) \end{aligned} \quad (4)$$

对于序列中的第 t 个商品,其随机嵌入将会被表示为一个 d 维的高斯分布 $\mathcal{N}(\mu_{s_t}, \Sigma_{s_t})$,其中 $\mu_{s_t} = \hat{E}_{\mu_{s_t}}, \Sigma_{s_t} = \text{diag}(\hat{E}_{\Sigma_{s_t}})$ 。

3.2 基于 Wasserstein 距离的随机自注意力编码器

由于使用随机嵌入层,Transformer 自注意力模块需要相应地进行修改。修改后的自注意力中的两个物品随机嵌入的点积如式(5)所示:

$$A_{ij} = -(W_2(s_i, s_j)) = -(\|\mu_{s_i} - \mu_{s_j}\|_2^2 + \|\Sigma_{s_i}^{1/2} - \Sigma_{s_j}^{1/2}\|_F^2) \quad (5)$$

式中: $W_2(\cdot, \cdot)$ 表示 2-Wasserstein 距离; $\mu_{s_i} = \hat{E}_{\mu_{s_i}} W_{\mu_K}; \Sigma_{s_i} = \text{ELU}(\text{diag}(\hat{E}_{\Sigma_{s_i}} W_{\Sigma_K})) + 1; \mu_{s_j} = \hat{E}_{\mu_{s_j}} W_{\mu_Q}; \Sigma_{s_j} = \text{ELU}(\text{diag}(\hat{E}_{\Sigma_{s_j}} W_{\Sigma_Q})) + 1$, ELU 为指数线性单元激活函数; $W_{\mu_K}, W_{\Sigma_K}, W_{\mu_Q}$ 和 W_{Σ_Q} 是随机嵌入的线性映射。

得到两个物品的随机嵌入的点积后,计算注意力分数、前馈神经网络、残差连接和层归一化与原始 Transformer 类似,因此将 Wasserstein 编码器表示为 $f(\cdot)$,最后输出为:

$$h_{u,t} = f(\hat{E}_{\mu_{s_u}}, \hat{E}_{\Sigma_{s_u}}) \quad (6)$$

式中: $h_{u,t} = (h_{\mu_{u,t}}, h_{\Sigma_{u,t}})$ 编码表示下一项, h_{μ_u}, h_{Σ_u} 是 S_u 经过随机嵌入层和 Wasserstein 编码器 f 后的表征, t 表示交互项。

3.3 基于实例加权动量对比学习的编码器

基于实例加权动量对比学习的编码器由动量对比学习和实例加权两个部分组成,如图 2 所示。

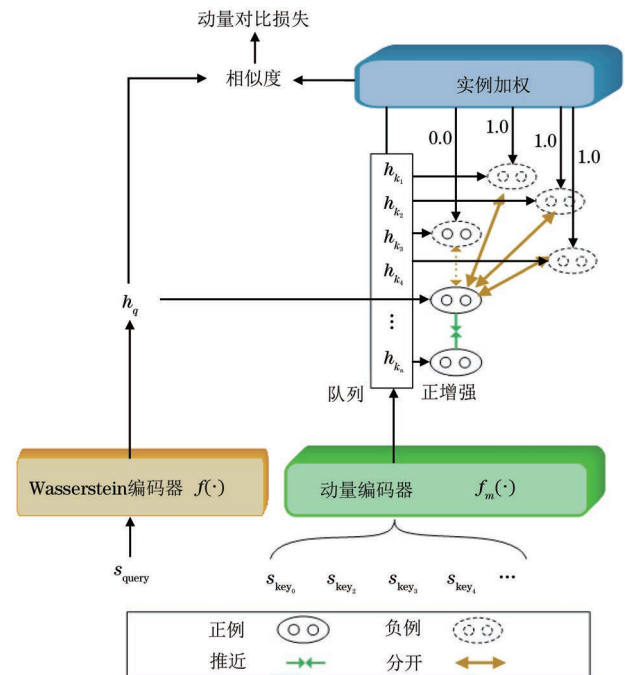


图 2 动量对比和实例加权

Fig. 2 Momentum contrast and instance weighting

3.3.1 动量对比学习

动量对比学习的关键在于保留一个数据样本的

队列,使模型可以重新利用之前几个小批次中编码的键(即 h_{k_i})。一旦队列建立,其大小就不再依赖于小批次的大小,引入队列的目的是将字典大小与小批量大小分离。队列的大小是一个可以独立动态调整的超参数,这意味着队列的容量能够远超正常的小批次大小。与此同时,在训练过程中,队列中的样本会被随机选择的序列增强的物品样本逐步替换,即当前小批量将排入字典,并删除队列中最早的小批量。

因为使用了队列,对应的问题是字典变大会导致通过反向传播来更新键编码器变得困难(梯度应传播到队列中的所有样本)。一个解决方案是将查询编码器 f (即基于 Wasserstein 距离的随机自注意力编码器)直接复制到键编码器 f_m (即基于实例加权动量对比学习的编码器),而无需考虑梯度更新。然而,由于编码器的快速变化,这种方法的效果不理想^[28]。因此,本文采用一种动量更新机制来应对这个问题,设 θ_k 为 f 的参数, θ_k 为 f_m 的参数, θ_k 的更新方式如下:

$$\theta_k \leftarrow m\theta_k + (1-m)\theta_q \quad (7)$$

式中: $m \in [0,1]$ 是动量系数, m 采用一个接近于1的值(如0.99),保证 f_m 能够缓慢更新。

3.3.2 实例加权

动量更新机制通过生成动态队列和移动平均编码器提升了模型的代表能力。然而,在推荐系统中存在采样偏差的问题。当将动量更新机制应用于序列推荐任务时,队列中抽取的负样本可能与正样本相似,导致假阴性样本的出现。这种采样偏差主要源于热门物品偏差和负样本选择偏差。热门物品偏差使模型过于依赖受欢迎物品的反馈,而动态队列中的表示随训练过程变化,使抽取的负样本可能与正样本相似,影响模型的效果^[29-30]。为了解决这个问题,本文采用一种负样本加权方法^[31]来惩罚假阴性,将编码器 f 、 f_m 生成的表征 $h_{\mu,t}$ 分别视为 h_q 、 h_{k_i} 。如图2所示,考虑一个正样本 h_q 和一组负样本 $h_{k_1}, h_{k_2}, \dots, h_{k_i}$ 则权重 $\alpha_{h_{k_i}}$ 可生成为:

$$\alpha_{h_{k_i}} = \begin{cases} 0, & W_2(h_q, h_{k_i}) \geq \phi \\ 1, & W_2(h_q, h_{k_i}) < \phi \end{cases} \quad (8)$$

式中: ϕ 是一个负样本加权阈值超参数; $W_2(h_q, h_{k_i})$ 可看作是相似度分数。因此,与正样本相似度最高的负样本将被视为假负样本,并将受到权重为0的惩罚。

$$\mathcal{L}_{cl}(h_q, h_{k_i}) = -\log_a \frac{\exp(W_2(h_q, h_{k_i}))}{\exp(W_2(h_q, h_{k_i})) + \alpha_{h_{k_i}} \times \sum_{j \in S_{B-}} \exp(W_2(h_q, h_{j,k_i}))} \quad (12)$$

3.3.3 与其他对比学习方法的区别

对比学习的主流方法主要有基于端到端和采用记忆库的方法。端到端方法在确保键一致性时,小批次大小受到 GPU 内存的限制,进而限制了模型的有效性^[32]。采用记忆库的方法则将数据集中所有样本的表示形式存储在记忆库中,每个小批量的队列可以从记忆库中随机抽取,从而使用较大的队列。然而,由于记忆库中的表示会随每一步训练变化,抽样的键可能会出现不一致的问题^[28]。为了解决这些问题,本文采用一种基于动量更新的编码器方法,对键进行动态编码并维护一个键队列^[28],动量对比学习在队列的大小和均匀性方面具备显著优势,因此本文选择动量更新的方法进行序列推荐中的对比损失计算。动量编码器通过缓慢更新参数保持历史信息,从而减少键的不一致性问题,提高了对比学习的效果。

3.4 损失计算

本文整体的损失函数如下:

$$L = L_{rec} + \lambda_{cl} L_{cl} \quad (9)$$

式中: L_{rec} 为推荐损失; L_{cl} 为对比学习损失; λ 为超参数。

3.4.1 推荐损失

推荐损失定义如下:

$$L_{rec} = \sum_{S_u \in S} \sum_{t=1}^{|S_u|} -\log_a(\sigma(W_2(h_{u,t}, s_{t+}) - W_2(h_{u,t}, s_{t-}))) + \lambda L_{pvm} \quad (10)$$

式中: s_{t+} 是真实的下一个物品的随机嵌入; s_{t-} 表示负采样物品项的嵌入; $\sigma(\cdot)$ 表示 Sigmoid 激活函数; L_{pvm} 是正负样本损失。

3.4.2 对比损失

对比学习中常采用 InfoNCE 作为损失函数,最小化 InfoNCE 等价于最大化互信息的下界^[32],因此本文的对比损失也采用 InfoNCE 实现。具体来说,在一个包含 N 个用户序列的批次中,通过 a 和 b 两种数据增强后会生成每个序列的两个扰动视图,从而得到 $2N$ 个序列,进而得到 N 对正样本对和 $4N^2 - 2N$ 对负样本对。对于包含 N 个用户序列的批次 B ,增强后的样本对 S_B 如下:

$$S_B = \{S_{u_1,a}, S_{u_1,b}, S_{u_2,a}, S_{u_2,b}, \dots, S_{u_N,a}, S_{u_N,b}\} \quad (11)$$

式中:下标 a 和 b 表示 S_u 的两个扰动。序列增强后得到 $(S_{u_i,a}, S_{u_i,b})$,结合权重,本文使用的对比损失定义如下:

式中: h_q 和 h_{k_i} 是从编码器 $f(\cdot)$ 和 $f_m(\cdot)$ 中学习之后的两个扰动序列版本的序列嵌入; $S_{B-} = S_B - \{S_{u_i,a}, S_{u_i,b}\}$ 表示负增广序列对。

4 实验

4.1 实验设置

4.1.1 数据集

本文采用 Beauty、Toys、Office、Yelp 4 个基准

数据集进行实验。数据集中如果用户对物品进行了评分或评论,那么该用户与物品间就存在交互。对于每个用户,则根据时间戳对交互的物品进行排序,形成交互序列。在每个用户序列中,使用最后一个交互物品作为待预测物品。与 SASRec 等^[16-17,33-34]类似,本文对用户采用 5-core 设定,过滤掉交互少于 5 次的用户。表 1 所示为数据集的统计信息。

表 1 不同数据集统计信息

Table 1 Statistical information of different datasets

数据集	用户数量/个	物品数量/个	交互数量/个	密度/%	每个用户的平均交互次数/次
Beauty	22 363	12 101	198 502	0.05	8.3
Toys	19 412	11 924	167 597	0.07	8.6
Office	4 905	2 420	134 476	0.44	10.8
Yelp	30 431	20 033	316 354	0.05	10.3

4.1.2 评估指标

本文采用 HR@K、NDCG@K 和 MRR 3 个指标进行性能评估。在 HR@K 和 NDCG@K 中, K 分别为 5、10。HR@K、NDCG@K 和 MRR 的区别在于:HR@K 衡量前 K 个推荐项物品是否包含真实物品的命中率,NDCG@K 考虑推荐结果的顺序对相关性的打分进行归一化,MRR 按照查询找到的第一个相关项目的倒数排名来计算平均排名。

4.1.3 基线模型

为了验证本文方法的有效性,实验将本文提出的方法与 7 种基线方法进行比较。这些基线模型可被分为 3 类:静态推荐方法 BPR-MF^[35],无监督序列推荐 SASRec^[17]、BERT4Rec^[16]、STOSA^[27],自监督学习的序列推荐 CLASRec^[18]、CoSeRec、Mstein。

BPR-MF:一个典型的矩阵分解模型。

SASRec:使用自注意力模块模拟用户序列,以识别用户的动态兴趣。

BERT4Rec:在 SASRec 的基础上添加了双向自注意力模块,进而提升推荐性能。

STOSA:使用 Wasserstein 距离来衡量物品间的差异性,以提升推荐性能。

CLASRec:将自监督学习和基于 Transformer 的序列推荐相结合,实现推荐性能的提升。

CoSeRec:提出了鲁棒的信息序列增强方法,将对自监督学习与序列推荐统一起来。

Mstein:通过最小化用户和物品之间的分布差异来提升推荐准确性和鲁棒性。

4.1.4 实验细节

模型使用 PyTorch 框架实现,分别在 $[0, 1, 0.9]$ 的值域内进行 ϕ 调优,在 $[0, 5]$ 的值域内进行

λ_d 调优,在 $[96\ 000, 448\ 000]$ 的值域内进行 k 调优,在 $[1, 5]$ 的值域内进行 l 调优。在验证集上进行 60 次 Epoch 后,如果性能没有提高,实验将提前停止并在测试集上报告结果。根据文献^[28, 36]使用 Adam 优化器在 $lr=0.001$ 、 $\beta_1=0.9$ 、 $\beta_2=0.999$ 和批次大小为 512 时对模型进行微调。

4.2 整体性能比较

如表 2~表 5 所示,在 Beauty、Office、Toys 和 Yelp 4 个数据集上进行的实验结果表明,本文方法在所有评估指标上均优于现有方法,尤其在 HR@1 和 NDCG@10 等关键指标上表现突出。例如,在 Beauty 数据集上,本文方法在 NDCG@10 上提升了 5.4%;在 Toys 和 Yelp 数据集上,NDCG@10 和 NDCG@5 的提升率分别为 3.053% 和 4.138%;在 Office 数据集上,NDCG@5 和 NDCG@10 分别提升了 6.055% 和 7.815%。综上,本文方法在推荐准确性和排序性能上显著优于现有方法,特别是在高阶评价指标 NDCG 上,展现出其在提升用户推荐体验方面的强大实用性。

表 2 不同方法在 Beauty 数据集上的性能比较

Table 2 Performance comparison of different methods

on the Beauty dataset

方法	HR@5	HR@10	NDCG@5	NDCG@10
BPR-MF	0.030 0	0.047 1	0.018 9	0.024 5
SASRec	0.041 6	0.063 3	0.027 4	0.034 3
BERT4Rec	0.039 6	0.059 5	0.025 7	0.032 1
CLASRec	0.053 8	0.072 6	0.034 9	0.041 2
CoSeRec	0.052 4	0.073 8	0.035 1	0.042 5
STOSA	0.050 4	0.070 7	0.035 1	0.041 6
Mstein	0.055 1	0.077 4	0.039 2	0.046 3
本文方法	0.056 2	0.078 4	0.039 9	0.048 8
提升比率/%	1.996 0	1.292 0	1.786 0	5.400 0

表 3 不同方法在 Toys 数据集上的性能比较

Table 3 Performance comparison of different methods on the Toys dataset

方法	HR@5	HR@10	NDCG@5	NDCG@10
BPR-MF	0.030 1	0.046 0	0.019 4	0.024 5
SASRec	0.055 1	0.079 7	0.037 7	0.045 6
BERT4Rec	0.030 0	0.046 6	0.020 6	0.026 0
CLASRec	0.061 7	0.076 4	0.042 4	0.045 4
CoSeRec	0.058 4	0.079 1	0.040 8	0.047 4
STOSA	0.057 7	0.080 0	0.041 2	0.048 1
Mstein	0.063 7	0.082 2	0.045 7	0.052 4
本文方法	0.064 8	0.083 5	0.046 9	0.054 0
提升比率/%	1.727 0	1.582 0	2.626 0	3.053 0

表 4 不同方法在 Yelp 数据集上的性能比较

Table 4 Performance comparison of different methods on the Yelp dataset

方法	HR@5	HR@10	NDCG@5	NDCG@10
BPR-MF	0.012 7	0.021 6	0.008 2	0.011 1
SASRec	0.016 0	0.026 0	0.010 1	0.013 3
BERT4Rec	0.019 6	0.033 9	0.012 1	0.016 7
CLASRec	0.022 7	0.038 4	0.014 3	0.019 4
CoSeRec	0.022 9	0.037 9	0.014 5	0.019 7
STOSA	0.018 2	0.030 7	0.011 3	0.015 3
Mstein	0.017 6	0.029 6	0.011 2	0.015 1
本文方法	0.023 2	0.040 4	0.015 1	0.020 1
提升比率/%	1.310 0	5.208 0	4.138 0	2.030 0

表 5 不同方法在 Office 数据集上的性能比较

Table 5 Performance comparison of different methods on the Office dataset

方法	HR@5	HR@10	NDCG@5	NDCG@10
BPR-MF	0.021 4	0.030 6	0.014 4	0.017 3
SASRec	0.065 6	0.098 9	0.042 8	0.053 4
BERT4Rec	0.048 5	0.084 8	0.030 9	0.042 6
CLASRec	0.070 9	0.109 1	0.047 1	0.059 4
CoSeRec	0.071 8	0.102 4	0.048 3	0.059 8
STOSA	0.067 7	0.102 1	0.046 1	0.057 2
Mstein	0.074 0	0.115 5	0.051 2	0.062 7
本文方法	0.075 8	0.118 4	0.054 3	0.067 6
提升比率/%	2.432 0	2.511 0	6.055 0	7.815 0

4.3 消融实验

为了评估本文所提方法中各模块的性能,本文在来自亚马逊评论的 Beauty、Office、Yelp 和 Toys 4 个数据集上进行了消融实验。这些实验有助于评估每个模块的独立贡献和整体方法的有效性。本文提出的方法包含基于对比学习方法的序列推荐损失计算部分(CL)、基于 Wasserstein 距离的随机自注意力编码器模块(WE)和基于实例加权的动量对比

学习模块(ME)。

为了验证这些模块的有效性,设置了以下实验:1)基于 Transformer 的序列推荐方法(TF),仅使用基于 Transformer 的编码器作为序列编码器,去掉基于 Wasserstein 距离的随机自注意力编码器模块和基于实例加权动量对比学习模块;2)基于对比学习的方法(CL),在 Transformer 序列推荐方法的基础上增加对比学习方法;3)基于动量对比学习模块的方法(ME),使用传统基于 Transformer 的编码器作为序列编码器,同时增加了基于实例加权动量对比学习模块;4)基于 Wasserstein 距离的随机自注意力编码器模块(WE),使用基于 Wasserstein 距离的随机自注意力编码器作为序列推荐方法的编码器,并结合对比学习方法。

消融实验结果如表 6 所示,TF 在各数据集上表现最差,无法充分捕捉序列数据中的复杂动态特性。CL 显著提升了性能,但仍受限于动态不确定性和采样偏移问题。ME 的引入进一步提升了 HR 和 NDCG 等指标,表明其有效缓解了采样偏移问题,最终结合 WE 模型在处理序列数据的动态不确定性方面表现更佳。本文方法在 Beauty、Toys、Yelp 和 Office 数据集上均优于其他模型,尤其在 HR 和 NDCG 指标上表现突出,显示出其在提升推荐准确性和处理动态不确定性方面的显著优势。

表 6 消融实验

Table 6 Ablation experiments

数据集	方法	HR@5	HR@10	NDCG@5	NDCG@10
Beauty	本文方法	0.056 2	0.078 4	0.039 9	0.048 8
	TF	0.039 1	0.062 5	0.023 6	0.032 3
	ME	0.052 4	0.068 7	0.035 4	0.042 1
	CL	0.051 2	0.076 3	0.034 1	0.039 6
	WE	0.051 8	0.071 7	0.035 1	0.041 6
Toys	本文方法	0.064 8	0.083 5	0.046 9	0.054 0
	TF	0.055 4	0.079 7	0.037 7	0.046 6
	ME	0.058 4	0.080 3	0.042 8	0.049 4
	CL	0.061 2	0.076 4	0.042 4	0.045 4
	WE	0.056 6	0.081 3	0.041 2	0.048 1
Yelp	本文方法	0.023 2	0.040 4	0.015 1	0.020 1
	TF	0.015 4	0.025 0	0.011 1	0.013 4
	ME	0.022 5	0.039 6	0.013 5	0.019 9
	CL	0.022 3	0.039 1	0.014 0	0.018 2
	WE	0.017 8	0.030 1	0.011 2	0.015 5
Office	本文方法	0.075 8	0.118 4	0.054 3	0.067 6
	TF	0.067 7	0.099 3	0.042 8	0.053 4
	ME	0.069 3	0.101 1	0.050 7	0.063 2
	CL	0.072 2	0.108 8	0.046 4	0.057 9
	WE	0.067 7	0.102 1	0.046 1	0.057 2

4.4 鲁棒性分析

为验证所提出的方法的鲁棒性,本文设置了 3 个实验:训练数据集比率的鲁棒性,噪声相互作用的鲁棒性和批量大小的鲁棒性,并对 3 种情况进行了鲁棒性实验分析。

4.4.1 训练数据集比率的鲁棒性

图 3 展示了在 Office、Beauty 和 Toys 3 个数据集上不同训练数据比例(从 10%~90%)下本文方法与 CoSeRec 方法的 MRR 表现。通过分析可以得出以下结论:

随着训练数据比例的增加,本文方法和




图 3 不同训练数据比例的鲁棒性
Fig.3 Robust over different training data ratios

4.4.2 噪声相互作用的鲁棒性

图 4 展示了在 Beauty、Office 和 Toys 数据集上不同噪声比例(从 0.1~0.9)下本文方法与 CoSeRec 方法的 MRR 表现。图 4 是噪声比例鲁棒性分析实验,横轴表示噪声比例,纵轴表示 MRR 值。通过对图中结果的分析,可以得出以下结论:

随着噪声比例的增加,本文方法和 CoSeRec 方法的 MRR 值均呈下降趋势,表明噪声对推荐系统性能有负面影响。然而,本文方法在多数情况下优于 CoSeRec 方法,尤其在低噪声(0.1~0.3)和中等

CoSeRec 方法的 MRR 值均有所上升,表明更多训练数据提升了推荐系统的性能。本文方法在各个训练数据比例下均优于 CoSeRec 方法,尤其在低(10%~30%)和中等(40%~60%)训练数据比例时表现突出。例如,在 10%训练数据时,本文方法在 Office 数据集上的 MRR 值为 0.035,而在 CoSeRec 方法为 0.025;在 40%数据比例下,本文方法在 Office 数据集上的 MRR 值约为 0.06,高于 CoSeRec 方法;在高训练数据比例(70%~90%)时,尽管差距缩小,本文方法仍略高于 CoSeRec 方法,表现出更好的稳定性和推荐准确性。

噪声比例(0.4~0.6)下表现突出。在低噪声比例时,本文方法在所有数据集上的 MRR 值均高于 CoSeRec,显示出更强的鲁棒性;在中等噪声比例时,尽管 MRR 值有所下降,本文方法仍高于 CoSeRec 且表现平稳。即使在高噪声比例(0.7~0.9)下,虽然两种方法的 MRR 值显著降低且差距缩小,但本文方法在多数情况下仍略优于 CoSeRec,显示出一定优势。综上所述,本文方法在各噪声比例下均优于 CoSeRec,特别是在低和中等噪声比例下表现更为鲁棒。




图 4 不同噪声比例下的鲁棒性
Fig.4 Robust over different noise ratios

4.4.3 批量大小的鲁棒性

图 5 展示了在 Beauty、Office 和 Toys 3 个数据集上不同批次大小(16~1 024)下本文方法与 CoSeRec 方法的 MRR 表现。通过对图中结果的分析可以综合得出结论:

随着批次大小的增加,本文方法和 CoSeRec 方

法的 MRR 值总体上升,表明更大的批次大小有助于提升推荐系统性能。总体来看,本文方法在大多数批次大小下优于 CoSeRec 方法,特别是在高批次大小时更为显著。在低批次大小(16~64)时,两种方法的 MRR 值接近但波动较大,本文方法在 Beauty 和 Toys 数据集上略有优势但不稳定;在中

等批次大小(128~256)时,本文方法表现更稳定且 MRR 值显著提升,特别在 Beauty 和 Office 数据集上显著优于 CoSeRec;在高批次大小(512~1 024)时,本文方法的 MRR 值在所有数据集上均远超

CoSeRec 方法,特别是在 Beauty 和 Toys 数据集上达到最高值。综上所述,本文方法在各批次大小下均优于 CoSeRec,尤其是在高批次大小时表现突出,显示出更好的推荐性能和稳定性。




图 5 不同批次大小的鲁棒性

Fig.5 Robust over different batch sizes

5 结束语

本文针对序列推荐中的动态不确定性和对比学习中的采样偏移问题,提出一种基于随机自注意力和动量对比学习的自监督序列推荐方法。该方法通过随机嵌入层和基于 Wasserstein 距离的随机自注意力编码器,增强模型对用户行为动态不确定性的适应性。同时,引入基于实例加权动量对比学习的编码器,极大地扩展了负样本的选取范围,并通过加权采样技术缓解假阴性样本的影响,提升了模型的鲁棒性和准确性。在 Beauty、Office、Yelp 和 Toy 4 个数据集上的实验结果表明,本文方法在准确性和鲁棒性方面均优于现有的基线方法。此外,对噪声相互作用和批次大小的敏感性分析进一步验证了所提方法的鲁棒性。未来的研究可以考虑将本文方法应用于更大规模和更多样化的数据集上,进一步验证其通用性和实用价值。

参考文献

- [1] WANG S, GONG J, WANG J, et al. Attentional graph convolutional networks for knowledge concept recommendation in MOOCs in a heterogeneous view[C]// Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2020: 79-88.
- [2] LIU Z, LI X, FAN Z, et al. Basket recommendation with multi-intent translation graph neural network [C]// Proceedings of the IEEE International Conference on Big Data. Washington D. C., USA: IEEE Press, 2020: 728-737.
- [3] 李忠伟, 周洁, 刘昕, 等. 融合时间和知识信息的生成对抗网络序列推荐算法[J]. 计算机工程, 2024, 50(11): 70-79. LI Z W, ZHOU J, LIU X, et al. Sequence recommendation algorithm based on generative adversarial network integrating time and knowledge information[J]. Computer Engineering, 2024, 50(11): 70-79. (in Chinese)
- [4] LIN X, ILIA P, SOLANKI S, et al. Phish in sheep's clothing: exploring the authentication pitfalls of browser fingerprinting[C]// Proceedings of the 31st USENIX Security Symposium. Washington D. C., USA: IEEE Press, 2022: 1651-1668.
- [5] LIN X, ILIA P, PILAKIS J. Fill in the blanks: empirical analysis of the privacy threats of browser form autofill[C]// Proceedings of the 2020 ACM SIGSAC Conference on Computer and Communications Security. New York, USA: ACM Press, 2020: 507-519.
- [6] 杨纪元, 马沐阳, 任鹏杰, 等. 基于自监督的预训练在推荐系统中的研究[J]. 山东大学学报(理学版), 2024, 59(7): 1-26. YANG J Y, MA M Y, REN P J, et al. Research on self-supervised pre-training for recommender systems[J]. Journal of Shandong University (Science Edition), 2024, 59(7): 1-26. (in Chinese)
- [7] 倪文锴, 杜彦辉, 马兴帮, 等. 面向个性化推荐的 node2vec-side 融合知识表示[J]. 计算机应用研究, 2024, 41(2): 361-367, 374. NI W K, DU Y H, MA X B, et al. Node2vec-side fusion knowledge representation for personalized recommendation [J]. Application Research of Computers, 2024, 41(2): 361-367, 374. (in Chinese)
- [8] ZHOU K, WANG H, ZHAO W X, et al. S-3-Rec: self-supervised learning for sequential recommendation with mutual information maximization [C]// Proceedings of the 29th ACM International Conference on Information & Knowledge Management. New York, USA: ACM Press, 2020: 1893-1902.
- [9] WU J, WANG X, FENG F, et al. Self-supervised graph learning for recommendation [C]// Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2021: 726-735.
- [10] WANG C, MA W, CHEN C, et al. Sequential recommendation with multiple contrast signals [J]. ACM Transactions on Information Systems, 2023, 41(1): 11-27.
- [11] FAN Z, LIU Z, PENG H, et al. Mutual Wasserstein discrepancy minimization for sequential recommendation [C]// Proceedings of the International World Wide Web Conferences. Washington D. C., USA: IEEE Press, 2023: 1375-1385.
- [12] ZIMDARS A, CHICKERING D M, MEEK C. Using temporal data for making recommendations [C]// Proceedings of the 17th Conference on Uncertainty in Artificial Intelligence. Seattle, USA: Morgan Kaufmann Publishers Inc., 2001: 580-588.
- [13] YAP G E, LI X L, YU P S. Effective next-items

- recommendation via personalized sequential pattern mining[C]//Proceedings of the 17th International Conference on Database Systems for Advanced Applications. Berlin, Germany: Springer, 2012: 48-64.
- [14] LI J, REN P, CHEN Z, et al. Neural attentive session-based recommendation [C] // Proceedings of the 26th ACM International Conference on Information and Knowledge Management. New York, USA: ACM Press, 2017: 1419-1428.
- [15] TAN Y K, XU X, LIU Y. Improved recurrent neural networks for session-based recommendations [EB/OL]. [2024-07-01]. <https://arxiv.org/abs/1606.08117>.
- [16] SUN F, LIU J, WU J, et al. BERT4Rec: sequential recommendation with bidirectional encoder representations from Transformer[EB/OL]. [2024-07-01]. <https://arxiv.org/abs/1904.06690>.
- [17] KANG W C, MCAULEY J. Self-attentive sequential recommendation[EB/OL]. [2024-07-01]. <http://arxiv.org/abs/1808.09781>.
- [18] XIE Z X, LI J Y. Contrastive learning for sequential recommendation[EB/OL]. [2024-07-01]. <https://arxiv.org/abs/2010.14395>.
- [19] 王帅, 史艳翠. 基于个性化数据增强的自监督序列推荐算法[J]. 计算机工程, 2025, 51(8): 190-202.
WANG S, SHI Y C. Self-supervised sequence recommendation algorithm based on personalized data augmentation[J]. Computer Engineering, 2025, 51(8): 190-202. (in Chinese)
- [20] MA J, ZHOU C, YANG H, et al. Disentangled self-supervision in sequential recommenders[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York, USA: ACM Press, 2020: 483-491.
- [21] YU J, YIN H, LI J. Self-supervised multi-channel hypergraph convolutional network for social recommendation[C]//Proceedings of the Web Conference. New York, USA: ACM Press, 2021: 413-424.
- [22] YAO T, YI X, CHENG D Z, et al. Self-supervised learning for large-scale item recommendations[EB/OL]. [2024-07-01]. <http://arxiv.org/abs/2010.11459>.
- [23] BOJCHEVSKI A, GUNNEMANN S. Deep Gaussian embedding of graphs: unsupervised inductive learning via ranking[EB/OL]. [2024-07-01]. <https://arxiv.org/abs/1707.03815>.
- [24] HE S, LIU K, JI G, et al. Learning to represent knowledge graphs with Gaussian embedding[C]//Proceedings of the 24th ACM International Conference on Information and Knowledge Management. New York, USA: ACM Press, 2015: 623-632.
- [25] SUN C, YAN H, QIU X, et al. Gaussian word embedding with a Wasserstein distance loss[EB/OL]. [2024-07-01]. <https://arxiv.org/abs/1808.07016>.
- [26] VILNIS L, MCCALLUM A. Word representations via Gaussian embedding[EB/OL]. [2024-07-01]. <https://arxiv.org/abs/1412.6623>.
- [27] FAN Z, LIU Z, WANG A, et al. Sequential recommendation via stochastic self-attention[C]//Proceedings of the ACM Web Conference. New York, USA: ACM Press, 2022: 325-336.
- [28] HE K, FAN H, WU Y, et al. Momentum contrast for unsupervised visual representation learning[EB/OL]. [2024-07-01]. <https://arxiv.org/abs/1911.05722>.
- [29] CHEN J, DONG H, WANG X, et al. Bias and debias in recommender system: a survey and future directions [J]. ACM Transactions on Information Systems, 2023, 41(3): 1-39.
- [30] VU T. Correct sampling bias for recommender systems [EB/OL]. [2024-07-01]. <https://towardsdatascience.com/correct-sampling-bias-for-recommender-systems-d2f6d9ddddec>.
- [31] ZHOU K, ZHANG B, ZHAO W X, et al. Debaised contrastive learning of unsupervised sentence representations[C]//Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. [S. l.]: ACL Press, 2022: 6120-6130.
- [32] 安永丽, 方斌, 刘劲芸, 等. 一种基于互信息神经估计改进的未知信道端到端通信系统[J]. 电讯技术, 2024, 64(9): 1386-1393.
AN Y L, FANG B, LIU J Y, et al. An improved end-to-end unknown channel communication system based on mutual information neural estimation [J]. Telecommunication Engineering, 2024, 64(9): 1386-1393. (in Chinese)
- [33] FAN Z, LIU Z, ZHENG L, et al. Modeling sequences as distributions with uncertainty for sequential recommendation [EB/OL]. [2024-07-01]. <https://arxiv.org/abs/2106.06165>.
- [34] LI J, WANG Y, MCAULEY J. Time interval aware self-attention for sequential recommendation[C]//Proceedings of the 13th ACM International Conference on Web Search and Data Mining. New York, USA: ACM Press, 2020: 3223-3235.
- [35] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: bayesian personalized ranking from implicit feedback[C]//Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence. Montreal, Canada: [s. n.], 2009: 3321-3335.
- [36] WEI Z, WU N, LI F, et al. MoCo4SRec: a momentum contrastive learning framework for sequential recommendation [J]. Expert Systems with Applications, 2023, 223: 119911.

文字编辑 索书志
栏目编辑 赖玉玲